

ANAHTARLAMALI DEVRELERİN YAPAY SİNİR AĞLARI VE FUZZY-NÖRAL AĞLAR İLE MODELLENMESİ VE SİMÜLASYONU

Yakup DEMİR

Ayşegül UÇAR

Fırat Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü ELAZIĞ
e-posta: ydemir@firat.edu.tr

Anahtar Sözcükler: Anahtarlama Devreler, YSA, ANFIS, Modelleme, Kümeleme

ABSTRACT

In recent years, the modelling and simulations of switched systems have gained importance. Here the modelling and simulations of a switched circuit are presented by using ANN (artificial neural networks) and ANFIS (adaptive network based fuzzy inference systems) and the performances of ANN and ANFIS have been compared. The computer programs used in this study are developed using MATLAB. From simulation results, it was demonstrated that ANFIS results in less training time and better performance than those of ANN. In addition, ANFIS applying "clustering algorithm" gives less parameter number, better performance and less training time than those of ANFIS applying "grid partition".

1.GİRİŞ

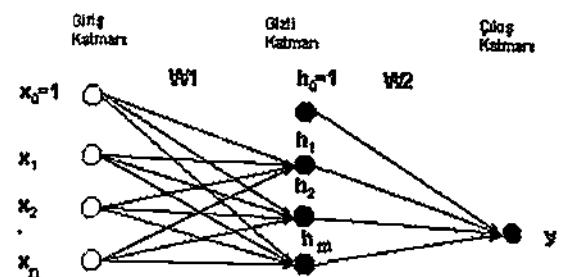
Son yıllarda, karakteristikleri lineer olmayan elektronik ve güç elektroniki devre elemanlarını içeren devrelerin analizi oldukça fazla önem kazanmıştır. Bunun için geliştirilen çok sayıdaki yöntemlerden biriside parça-parça lineerlik yaklaşımıdır. Lineer olmayan elemanların parça-parça lineer elemanlar olarak göz önüne alındığı bu yaklaşımda lineer olmayan elemanlar, lineer elemanlar, kaynaklar ve anahtarlardan oluşan eşdeğer devrelerle modellenmiştir[1]. Son yıllarda bu yaklaşımın önemini artırması nedeniyle anahtarlar vazgeçilmez devre elemanlarından birisi olmuştur.

Birçok araştırma alanında yeni bir ufuk açan yapay sinir ağları (YSA); paralel çalışabilme, genelleme ve özellikle öğrenebilme yeteneklerinden dolayı devre modellemelerinde çok geniş bir uygulama imkanı bulmuştur. YSA'ların yanı sıra, doğal sistemlerde sıradan kesin olmayan bilginin çeşitli gösterimi ile ilgilenen fuzzy mantık geliştirilmiş ve birçok alandaki başarılı uygulamasıyla fuzzy sistemlere ilgi gittikçe armuştur. Son yıllarda, YSA'lar ve fuzzy sistemler arasındaki lineer olmayan sistemleri modelleme yeteneklerinin benzerliği araştırılmış ve sonuçta ikisinin birleşimi olan nöro-fuzzy sistemler ile modelleme de gelişmiş görülmüştür [2-6].

Bu bildiride anahtarlama devreler, hem YSA ile hem de fuzzy sistemler ve YSA'ların avantajlarını birleştiren adaptif ağ temelli fuzzy çıkışlı sistemler (ANFIS) ile modellenmiştir. Bu amaçla MATLAB bilgisayar programı kullanılmıştır ve önek devreye ilişkin simülasyon sonuçları verilmiştir. Ayrıca YSA ve ANFIS modellerine ilişkin simülasyon sonuçları karşılaştırılmıştır.

2. MODEL YSA YAPISI

YSA lineer olmayan sistemleri modellemek için oldukça iyi sonuçlar veren bir ağ yapısıdır. Bu çalışmada, biasların birer yalancı giriş gibi düşünüldüğün tüm değiştirilebilir parametrelerin ağırlık matrisinin içinde olduğu Şekil 1'deki üç katmanlı ileri beslemeli YSA kullanılmıştır.



Şekil 1. Model YSA yapısı

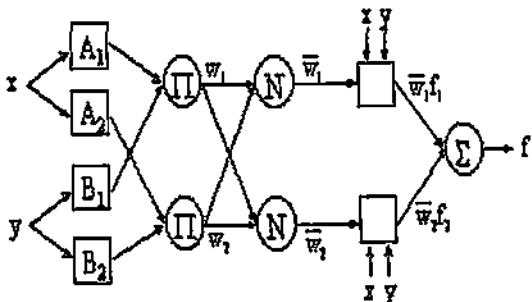
Bu yapıda, hem ağırlıklarını iteratif olarak çözmek için adaptif öğrenme oranı kullanan geriye yayılım metodu (YSA-1) hem de performans fonksiyonunun ikinci türevinden gelen ek bilgilerden dolayı daha hızlı olan Levenberg Marquardt metodu (YSA-2) kullanılmıştır [7-8].

3. MODEL ANFIS YAPISI

Fuzzy sistem ve nöral sistemler arasındaki en iyi geçişlerden birisi ANFIS'tir. Bu sistem, birinci dereceden Sugeno sistemin fuzzy sistem parametrelerini optimize etmek için melez öğrenme kuralını kullanır [9]. Tipik bir kural kümesi,

eger x , A_1 ve y , B_1 ise, o zaman $f_1 = p_1x + q_1y + r_1$
eger x , A_2 ve y , B_2 ise, o zaman $f_2 = p_2x + q_2y + r_2$.

gibi ifade edilen iki girişli, iki kurallı birinci dereceden Sugeno sistem Şekil 2' de blok olarak görülmektedir. Bu yapıda ANFIS için her bir katmana ilişkin tanımlar aşağıdaki gibidir.



katman 1 katman 2 katman 3 katman 4 katman 5

Şekil 2. İki girişli, iki kurallı birinci dereceden Sugeno model için ANFIS yapısı

1.Katman: Bu katmandaki her bir i düğümü Denklem (1) ile tanımlanan bir çıkış düğümü adaptif düğümdür. Burada; x ve y : düğüme ait giriş, A_j ve B_j : bir fuzzy kümeye ve $O_{1,i}$: katman1' deki i. çıkış düğümünü gösterir.

$$O_{1,i} = \mu_{A_j}(x), \quad j=1,2, \text{ için} \quad (1)$$

Bu çalışmada Denklem (2) ve (3) ile karakterize edilen gaussian ve yamuk Üyelik Fonksiyonları (ÜF) kullanılmıştır. Burada; $\{a_j, b_j, c_j, d_j, \sigma_j\}$ bu katmandaki lineer olmayan giriş parametreleri olarak ifade edilir.

$$\mu_{A_j}(x) = e^{-\left(\frac{x-a_j}{\sigma_j}\right)^2} \quad (2)$$

$$\mu_{A_j}(x) = \max \left(\min \left(\frac{x-a_j}{b_j-a_j}, 1, \frac{d_j-x}{d_j-c_j} \right), 0 \right) \quad (3)$$

2.Katman: Bu katmandaki her bir i düğümü Denklem (4)'de tanımlandığı gibi, gelen sinyalleri çarpan ve çıkış üreten iki sabit düğümdür.

$$O_{2,i} = w_i = \mu_{A_j}(x) * \mu_{B_j}(y), \quad i=1,2; j=1,2 \quad (4)$$

3.Katman: Bu katmanda Denklem (5)'de tanımlandığı gibi normalize edilmiş gerçekleşme dereceleri hesaplanır.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (5)$$

4.Katman: Bu katmandaki her bir i düğümü Denklem (6) ile tanımlanan düğüm fonksiyonu bir adaptif düğümdür. Burada; $\{p_i, q_i, r_i\}$ bu katmandaki lineer sonuç parametreleri olarak ifade edilir.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (6)$$

5.Katman: Bu katmandaki tek düğüm, gelen tüm sinyalleri toplayıp çıkış veren sabit bir düğümdür. 1. ve 4. katmanın değiştirilebilir parametrelerini içeren bu katmanda, parametrelerin ayarlanması ve öğrenilmesi 2 aşamada gerçekleşir. İlk aşamada, 1. katmandan elde edilen parametreler sabit tutulup en küçük kareler algoritması uygulanır. İkinci aşamada ise, 4. katmandan elde edilen parametreler sabit tutulup bilgi ağ içinde geriye yayılarak gradiente iniş algoritması uygulanır.

$$O_{5,i} = \text{tüm çıkış} = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i} \quad (7)$$

Bu çalışmada, kurallar ve ÜF sayısı iki yöntemle oluşturulmuştur. İlk yöntemde, girişler için ÜF sayıları belirlenip tüm ÜF'ler kuralları oluşturmak için kullanılmıştır. Bu kuralları oluşturma tarzı izgaralama böülünlendirmesi olarak isimlendirilir [10]. Bu metotta, girişlerin sayısı belli bir dereceye kadar arttığı zaman problemler ile karşılaşılır. Örneğin; 10 girişli ve her bir giriş iki ÜF ye sahip olan bir fuzzy model, mümkün olamayacak büyüklükteki ($2^{10}=1024$) fuzzy eğer o halde kuralla sonuçlanır. İkinci yöntemde, eksiltici kümeleme algoritması kullanarak ÜF'ler ve kuralları oluşturulmuştur. Eksiltici kümeleme, veri notalarının yoğunluk ölçüsünde dayanır [11]. Amaç, veri noktalarının yüksek yoğunluklu bölgelerini bulmaktır. En yüksek potansiyele sahip olan veri noktası küme için merkez olarak seçilir. Önceden belirlenmiş fuzzy yarıçapı içinde veri noktaları çıkarılır ve algoritma yüksek potansiyelli yeni veri noktaları arar. Tüm veri noktaları deneninceye kadar arama devam eder. K veri noktasının seçimi m boyutlu vektör tarafından belirlenir ve normalize edilip, u_k veri noktasındaki yoğunluk ölçüsü Denklem (8)'deki gibi tanımlanır.

$$D_k = \sum_{j=1}^K \exp \left(-\frac{\|u_k - u_j\|}{(r_a/2)^2} \right) \quad (8)$$

Burada; $k=1, 2, 3, \dots, K$ ve r_a pozitif bir sabittir. En yüksek yoğunluklu nokta birinci küme merkezi olarak seçilir. Seçilmiş nokta u_{c1} ve onun yoğunluk ölçüsü D_{c1} ile gösterilirse; her bir veri noktası u_k için yoğunluk ölçüsü, Denklem (9) ile tekrar düzeltildir.

$$D'_k = D_k - D_{c1} \exp \left(-\frac{\|u_k - u_{c1}\|}{(r_b/2)^2} \right) \quad (9)$$

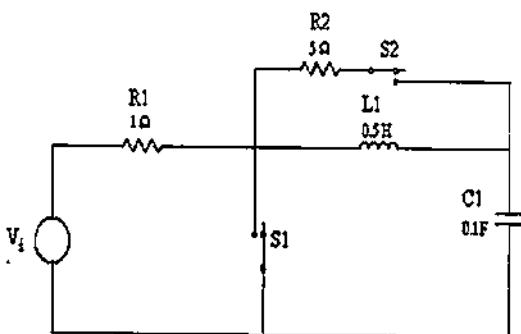
Burada, r_b yakın olan küme merkezlerini önlemek için r_a dan daha geniş almır. Bu nedenle ilk küme merkezi yakınındaki veri noktaları, u_{c1} yoğunluk ölçülerini oldukça azaltmış olacak ve muhtemelen bir sonraki küme merkezi olarak seçilmeyecektir. Her bir veri noktasının yoğunluk ölçüsü tekrar düzeltildikten

sonra, bir sonraki küme merkezi u_{c2} seçilir ve tüm yoğunluk ölçüleri tekrar düzeltılır. Kümeleme merkezlerinin yeterli bir sayısı oluşuncaya kadar işlem tekrar edilir. Giriş ve çıkış veri kümelerine eksiktici kümeleme algoritması uygulandığı zaman, kümeleme merkezlerinin her biri bir kural gösterir. Kuralları oluşturmak için küme merkezleri, bu algoritmada gausisan ÜF'ler için merkezler olarak kullanılır.

4. ÖRNEK

Lineer olmayan devrelerin, parça-parça lineerlik yaklaşımı ile modellenmesi sonucunda eşdeğer devrelerinde anahtarlarla ortaya çıkmaktadır. Anahtarların birbirlerine göre farklı kombinasyonları sonucunda her bir lineer bölgeye ilişkin modeller birlenip bu tek model üzerinde eğitim yapılarak devreye ilişkin simülasyon MATLAB bilgisayar programında gerçekleştirilmektedir.

Bu örnekte Şekil 3' deki anahtarlama devre ele alınmıştır. YSA'ının ve ANFIS'ın modelleme performanslarının açıkça görülebildiği bu devrede: 1. Durumda S1 ve S2 açık, 2. Durumda S1 açık - S2 kapalı, 3. Durumda S1 kapalı - S2 açık, 4. Durumda S1 ve S2 kapalı olup her bir sistem durumunda 1 saniye kalınlmaktadır. Devrede girişe göre modellenenek olan çıkış kondansatör üzerindeki gerilimdir.



Şekil 3. Örneğe ilişkin anahtarlama devre

YSA ile modelleme için istenilen hatayı verecek olan en küçük ağ olarak giriş ile geçirtilmiş giriş ve çıkışlardan oluşan 5 girişli, 6 gizli nöronlu ve gizli katmandaki aktivasyon fonksiyonu lojistik, çıkış katmanındaki aktivasyon fonksiyonu lineer olan Şekil 3' deki şık katmanlı ileri beslemeli YSA kullanılmıştır. ANFIS ile modelleme de ise beş girişli, bir çıkışlı ANFIS yapısı kullanılmıştır.

Bu örnekte önce, anahtarların yukarıda belirtilen kombinasyonları ile elde edilen tek model, YSA-1 ve YSA-2 ağlarının kullandığı yöntemlerle ayrı ayrı eğitilmiştir. Daha sonra, izgaralama yöntemi (ANFIS-1) ve kümeleme yöntemi (ANFIS-2) kullanarak

kuralları oluşturan ANFIS yapısı uygulanmıştır. Model YSA ve ANFIS yapıları karşılaştırılmıştır.

Model ağlar, iyi bir genelleme yapabilmek için Şekil 4' deki [-2:2] aralığında rasgele dağılmış giriş sinyalinin 1200 örneği kullanılarak eğitilmiştir. Bu veriler her bir bölge için devrenin durum denklemlerinden elde edilmiştir. Lineer olmayan sistemin önemli özelliklerinden biri başlangıç şartlarına göre nonlineerliğinin değişmesidir. Bu devrede de başlangıç şartları her bir sistem durumuna göre programda hesaplanmıştır. Toplam kare hatanın ortalamasının karekökü, birleşme kriteri olarak alınmıştır. Veri sayısı 1200 iken elde edilen sonuçlar Tablo 1'de görülmektedir.

Simülasyonlar sonucunda, YSA içindeki değiştirilebilir parametrelerin sayısı = (5 giriş nöronu * 6 gizli düğüm) - (1 giriş biası * 6 gizli düğüm) + (1 gizli düğüm biası * 1 çıkış) + (6 gizli düğüm * 1 çıkış düğümü) = 43 olarak elde edilmiştir.

ANFIS için MATLAB'ın Fuzzy Lojik Toolbox'ı kullanılmıştır. ANFIS-1 içindeki ayarlanabilen parametrelerin sayısı: giriş sayısı 5 ve her bir giriş için 2 yanık ÜF alındığında: ayarlanabilir lineer parametrelerin sayısı = (kural sayısı) * (giriş sayısı + 1) = $2^5 * (5+1) = 192$. ayarlanabilir lineer olmayan parametreleri sayısı = (ÜF parametre sayısı * ÜF sayısı * giriş sayısı) = $4 * 2 * 5 = 40$ ve toplam ayarlanabilir parametre sayısı = $192 + 40 = 232$ olarak elde edilmiştir. ANFIS-2 içindeki ayarlanabilen parametrelerin sayısı: giriş sayısı 5 ve her bir giriş için kullandığı 2 gausisan ÜF ve kural ile 32 olarak kendisi ayarlamaktadır. YSA-2 ve ANFIS-2'nin değiştirilebilir parametrelerinin listesi EK'te verilmiştir.

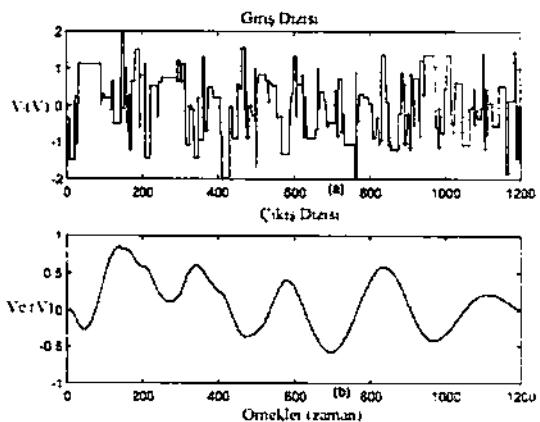
Model ağı performansını test etmek için birim basamak ve $\sin(0.1*t)$ girişleri kullanılmıştır. Tablolardan açıkça görüldüğü gibi YSA-2 ve ANFIS-2'ye ilişkin sonuçlar oldukça iyi olduğu için ve bildiri uzunluğunun sınırlı tutulması nedeniyle sadece YSA-1 ve ANFIS-1'e ilişkin sonuçlar verilmiştir. YSA-1 ve ANFIS-1 modellerine ilişkin simülasyon sonuçları: birim basamak giriş'i için Şekil 5 ve 6'da, $\sin(0.1*t)$ giriş'i için Şekil 7 ve 8'de görülmektedir. ANFIS-1 ve ANFIS-2 modelleri için çalışmadan sonraki ÜF'ler Şekil 9'da görülmektedir. Aynı işlemler, YSA ve ANFIS'ın eğitimi için rasgele dağılmış sinyalin 400 verisi kullanılarak yapılmıştır. Elde edilen sonuçlar Tablo 2'de görülmektedir. Tüm işlemler sonucunda ANFIS-2 modelin oldukça kısa bir sürede, diğerlerine göre hem daha az parametre sayısı ile hem de daha düşük hata ile sonuçlandığı ve az veri kullanılsa bile ANFIS-2'nin modelleme performansının iyi olduğu görülmektedir.

Tablo:1 Veri sayısı 1200 iken YSA ve ANFIS in modelleme performanslarının karşılaştırılması

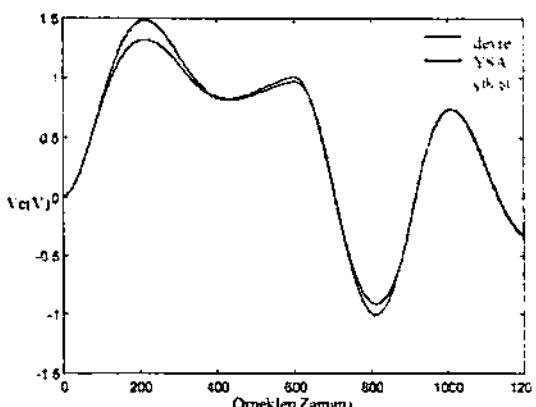
	Hata	Parametre sayısı	Eğitim süresi
YSA-1	0.0077	43	32 dakika
YSA-2	0.001	43	40 sn
ANFIS-1	0.000348	232	1 dakika
ANFIS-2	0.000305	32	40 sn

Tablo:2 Veri sayısı 400 iken eğitim hataları

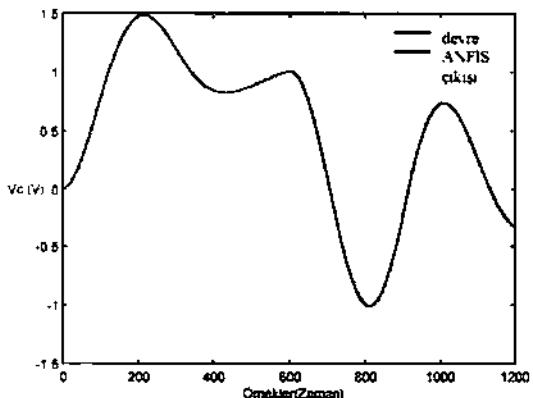
	Hata
YSA-1	0.009
YSA-2	0.0043
ANFIS-1	0.002843
ANFIS-2	0.001073



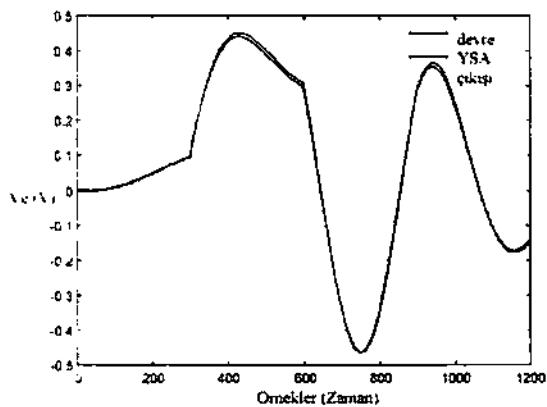
Şekil 4. YSA ve ANFIS modelleri eğitmek için a) [-2:2] aralığındaki rasgele dağılımlı giriş sinyali, b) rasgele dağılımlı giriş sinyaline Şekil 3' deki devrenin cevabı



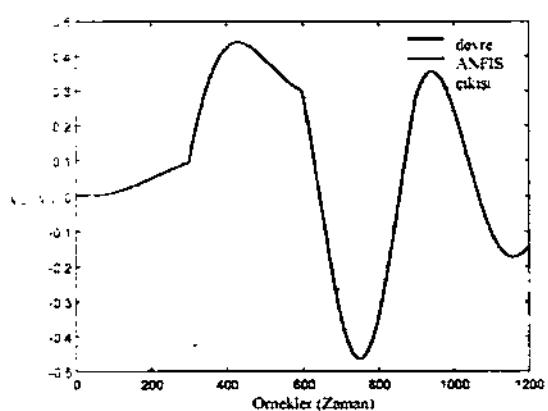
Şekil 5. Şekil 3' deki devrede birim basamak girişi için V_c ' ye ilişkin YSA-1 model ve devre çıkışı



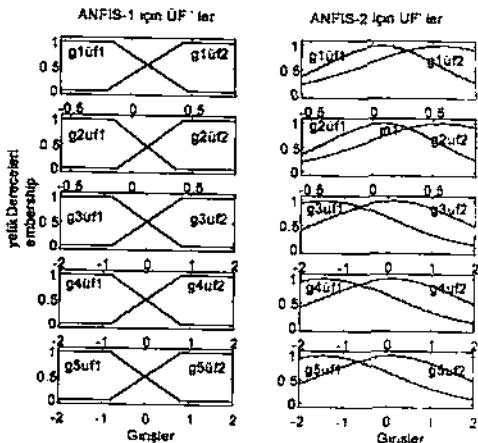
Şekil 6. Şekil 3' deki devrede birim basamak girişi için V_c ' ye ilişkin ANFIS-1 model ve devre çıkışı



Şekil 7. Şekil 3' deki devrede $V_i = \sin(0.1 * t)$ girişi için V_c ' ye ilişkin YSA-1 model ve devre çıkışı



Şekil 8. Şekil 3' deki devrede $V_i = \sin(0.1 * t)$ girişi için V_c ' ye ilişkin ANFIS-1 model ve devre çıkışı



Şekil 9. Çalışmadan sonraki ÜF'ler

5. SONUÇLAR

Bu çalışmada, YSA ve ANFIS kullanımlararak anahtarlamalı devrelerin modellenmesi yapılmıştır. Model YSA'ının eğitimi için iki farklı algoritma kullanılmıştır. Levenberg Marquard yönteminde performans fonksiyonunun ikinci türevinden gelen ek bilgiler de kullanıldığından hesapsal karmaşıklık daha fazla olmasına rağmen adaptif öğrenme oranını kullanan geriye yayılma metoduna göre daha hızlı olduğu gözlenmiştir. Model ANFIS'ın eğitimi için hem geriye yayılma hem de en küçük kareler algoritması kullanıldığından dolayı hesapsal karmaşıklık fazla olmasına rağmen eğitim süresinin kısa olduğu gözlenmiştir.

Kuralları oluşturmak için izgaralama böülümlendirmesi kullanan model ANFIS' de, oldukça küçük hata elde edilmesine rağmen çok fazla parametre sayısı dezavantaj oluşturmaktadır. Bu problem daha az parametreye sahip olan bir ÜF kullanılarak bir derece azaltılabilir fakat bu çalışmada sonuçları değiştirmez. Kümeleme algoritması kullanan ANFIS'ın eğitim süresi, parametre sayısı ve kullanılan hata bakımından YSA ve izgaralama böülümlendirmesi kullanan ANFIS'e göre çok iyi sonuç verdiği görülmüştür. Veri sayısı azaltılarak yapılan çalışma sonunda da yine ANFIS'ın YSA'ya göre daha iyi performans verdiği gözlenmiştir.

EK

Bu çalışmada YSA-2 modeli için elde edilen W1 ve W2 parametreleri ile ANFIS-2 için elde edilen kurallar ve parametreler aşağıdaki gibidir.

$$W1 = \begin{bmatrix} 0.5988 & 0.2780 & 0.4847 & -0.072^* & 0.7395 & 1.2642 \\ 0.4354 & -0.2172 & 0.0001 & 0.0000 & 0.0000 & -0.0279 \\ 0.3200 & 0.7230 & 0.7894 & 0.9831 & 0.3383 & 0.6729 \\ 0.2711 & 0.7937 & 1.1635 & 0.5495 & 0.2753 & 0.4992 \\ 0.4690 & 0.1458 & 0.6714 & 0.8432 & 0.0698 & 0.7049 \\ 0.3187 & 0.3316 & 1.1332 & 0.8761 & 0.5978 & 0.5030 \end{bmatrix}$$

$$W2 = \begin{bmatrix} -0.0008 & 4.5978 & 0.0054 & 0.0013 & -0.0343 & -0.0031 & 0.1287 \end{bmatrix}$$

Kural 1: eğer $g1, A_1$ ve $g2, B_1$ ve $g3, C_1$ ve $g4, D_1$ ve $g5, E_1$ ise. o halde:

$$V_1 = 1.996.g1 - 0.997.g2 + 0.0002.g3 + 0.0000.g4 + 0.0001.g5 - 0.0001.$$

Kural 2: eğer $g1, A_2$ ve $g2, B_2$ ve $g3, C_2$ ve $g4, D_2$ ve $g5, E_2$ ise. o halde:

$$V_2 = 1.990.g1 - 0.991.g2 - 0.0004.g3 + 0.0001.g4 - 0.0000.g5 - 0.0006.$$

Burada: $A_1, A_2; B_1, B_2; C_1, C_2; D_1, D_2; E_1, E_2$ sırasıyla aşağıdaki parametreler tarafından karakterize edilir.

$$\{0.4570, 0.0811\}, \{0.6363, 0.5846\}, \{0.457, 0.085\}, \{0.637, 0.5864\}, \{1.5517, 0.1257\}, \{1.5746, -1.443\}, \{1.5616, 0.1166\}, \{1.583, -1.434\}, \{1.5597, 0.1179\}, \{1.5823, -1.4357\}.$$

REFERENCES

- [1] Demir Y., Lineer Olmayan Devrelerin Durum Denklemlerinin Değişik Bölgeler İçin Bulunması ve Bölgeler Arası Geçişler İçin Anahtarlamalı Denklemlerin Hesaplanması. Doktora Tezi. Fırat Üniversitesi, Elazığ, 1993.
- [2] Karna K. and Breen D., An Artificial Neural Networks Tutorial :part1-basics, Neural Networks, vol. 1, no. 1, p. 4 -23, 1989.
- [3] Efe M. Ö, and Kaynak O., Comparative Study of Neural Network Structures in Identification of Nonlinear Systems. Mechatronics, vol. 9, no. 3, p. 287-300, 1999.
- [4] Zhang J. and Morris Julian A., Recurrent Neuro-Fuzzy Networks for Nonlinear Process Modeling, IEEE Transactions on Neural Networks, vol. 1, no. 2, p. 313-326, 1999.
- [5] Borchers C., Symbolic Behavior Model Generation of Nonlinear Analog Circuits, IEEE Transactions on Circuits and Systems, vol. 45, no. 10, p. 1362-1371, 1998.
- [6] Brown M. and Chris H., Nörofuzzy Adaptif Modelling and Control. Prentice Hall, 1994.
- [7] Hines J. W. Fuzzy and Neural Approaches in Engineering MATLAB Supplement. Prentice Hall, 1997.
- [8] Efe M. Ö. Identification and Control of Nonlinear Dynamical Systems Using Neural Networks. Boğaziçi Üniversitesi. Systems and Control Engineering, M.S. Thesis, 1996
- [9] Jang J. R. and Chuen-Tsai S., Neuro-Fuzzy Modeling and Control, Proceedings of the IEEE, vol. 83, no. 3, p. 378-406, 1995.
- [10] Jang J. R., Neuro-Fuzzy Modeling for Dynamic System Identification, Soft Computing in Intelligent Systems and Information Processing Proceedings of The Asian Fuzzy Systems Symposium, p. 320-325, 1996.
- [11] Jantzen J., Neurofuzzy Modelling, Technical Report 98-H-874, Department of Automation Technical University of Denmark, 1998.